

融合高效卷积注意力的时域卷积网络 短期负荷预测模型

孙东磊¹, 李文升¹, 梁 露², 张智晟²

(1. 国网山东省电力公司 经济技术研究院, 山东 济南 250021; 2. 青岛大学 电气工程学院, 山东 青岛 266071)

摘要:为避免时域卷积网络中膨胀卷积结构导致的负荷信息不连续现象,进一步提升预测模型对重要负荷特征的提取能力,本研究提出一种融合高效卷积注意力模块的混合膨胀卷积改进时域卷积网络(ECBAM-HTCN)的短期负荷预测模型。该模型以具备并行计算能力的时域卷积网络为基础学习负荷数据特征,通过构建混合膨胀卷积层改进时域卷积网络残差块,利用不同膨胀系数的卷积自适应地捕获不同距离下全部负荷数据,避免信息不连续;同时,引入能够自适应调整卷积核大小的一维卷积改进传统卷积注意力模块,高效捕获负荷数据空间和通道两个维度的重要信息。基于实际电网负荷数据仿真实验表明,在短期负荷预测任务中,所提出的 ECBAM-HTCN 模型具有较高的预测精度和较好的稳定性。

关键词:短期负荷预测;时域卷积网络;混合膨胀卷积;高效卷积注意力模块

中图分类号:TM715

文献标志码:A

Short-term load forecasting of power system based on temporal convolutional neural network fusion of efficient convolutional attention model

SUN Donglei¹, LI Wensheng¹, LIANG Lu², ZHANG Zhisheng²

(1. Economic and Technological Research Institute, State Grid Shandong Electric Power Company, Jinan 250021, China;

2. College of Electrical Engineering, Qingdao University, Qingdao 266071, China)

Abstract: To avoid the discontinuity issue caused by the dilated convolution structure in the temporal convolutional network and further enhance the ability to extract key load features, we propose a short-term load forecasting model called hybrid dilated convolution improved temporal convolutional network with efficient convolutional block attention model (ECBAM-HTCN). Based on the parallelizable temporal convolutional network, the load data features are learned and a hybrid dilated convolution layer is constructed to improve the residual block of the temporal convolutional network. This layer adaptively captures the complete load data at different distances using different dilation factors, thus avoiding information discontinuity. The traditional convolutional block attention module is improved by utilizing a one-dimensional convolution that can adaptively adjust the kernel size to efficiently capturing important information in both the spatial and channel dimensions of the load data. The results of simulations on actual power grid load data show that the proposed ECBAM-HTCN model achieves high forecast accuracy and stability.

Key words: short-term load forecasting; temporal convolutional network; hybrid dilation convolution; efficient convolutional block attention module

收稿日期:2024-03-20

基金项目:国网山东省电力公司科技项目(520625220001)

作者简介:孙东磊(1988—),男,山东济宁人,高级工程师,博士,主要研究方向为电力系统规划与预测管理。

张智晟(1975—),男,山东青岛人,教授,博士,主要研究方向为电力系统和综合能源系统负荷预测、经济调度等。本文通信作者。Email:slnzszs@126.com

可再生能源的大规模开发利用、电动汽车等柔性负荷的广泛普及,以及用户间、用户与能源系统间互动性的不断增强,显著提升了电力负荷变化的复杂性^[1-2]。在此背景下,实现高精度的电力系统短期负荷预测对于维持系统供需平衡的经济高效运行至关重要^[3]。

近年来,神经网络凭借其强大的多元非线性映射能力,在负荷预测领域受到广泛关注^[4-5]。其中,卷积神经网络(convolutional neural network, CNN)表现尤为突出^[6]。文献[7]利用自编码器预处理负荷数据及相关影响因素,并采用粒子群算法优化 CNN 参数,有效提升了模型的预测精度与速度。文献[8]将因果逻辑约束引入到全卷积网络结构中,并利用多尺度卷积提取不同时间尺度的负荷数据,显著提高了预测精度和稳定性。然而,受限于卷积核尺寸,传统 CNN 的感受野有限,难以有效捕捉长期负荷依赖特征^[9]。为克服此局限,文献[10]将膨胀因果卷积引入传统 CNN,并加入能够避免梯度消失的残差连接,构建了时域卷积网络(temporal convolutional network, TCN),不仅保留了 CNN 高效处理大规模数据的优势,还能通过膨胀卷积灵活扩展感受野,更加有效地提取长期负荷依赖信息。文献[11]利用时域卷积网络对电力负荷进行预测,验证了 TCN 相较于经典机器学习模型具有更高的预测精度。文献[12]从输入特征组合角度,结合 Holt-Winters 指数平滑与 TCN 构建预测框架,进一步提升了 TCN 的预测精度。但尽管 TCN 能够充分提取电力负荷数据特征,若不加区分地处理所有局部信息,将导致计算资源的大量消耗。文献[13]表明突出局部重要信息的注意力机制对于提高模型性能有极大帮助。文献[14]提出的卷积注意力模块(convolutional block attention module, CBAM)能有效整合通道与空间两个维度的重要负荷信息,但其结构中的全连接层在处理海量数据时,存在计算复杂度高的问题。

针对上述问题,本研究提出一种融合高效卷积注意力模块的混合膨胀卷积改进时域卷积网络的(hybrid dilated convolution improved temporal convolutional network with efficient convolutional block attention module, ECBAM-HTCN)短期负荷预测模型。首先,改进 CBAM 的通道注意力子模块,利用能够自动调整卷积核尺寸的一维卷积构建高效通道注意力子模块,减少参数量的同时有效捕捉局部跨通道交互信息;然后,将 CBAM 空间注意力子模块中的全连接层替换为一维卷积,进一步减少网络参数,由此构建的高效卷积注意力模块(efficient convolutional block attention module, ECBAM)能够增强模型对空间和通道两个维度的重要负荷数据的提取能力^[15],抑制不重要负荷信息的表达;最后,引入混合膨胀卷积结构改进 TCN,克服 TCN 中由于膨胀卷积结构导致的负荷信息不连续问题。基于某地区电网实际数据的仿真实验表明,ECBAM-HTCN 模型具有较好的预测稳定性和较高的预测精度。

1 高效卷积注意力模块

高效卷积注意力模块(ECBAM)由基于空间(spatial)维度和基于通道(channel)维度的两个独立注意力子模块构成,能够同时从空间和通道两个维度强化对重要负荷数据的提取能力。如图 1 所示,该模块首先利用高效通道注意力子模块对输入数据进行通道维度的探索,提取通道维度的重要信息,加权到原始输入数据上,再经空间注意力子模块,捕捉输入数据在空间维度上的依赖关系,突出重要信息表达,抑制不重要信息,得到具有通道和空间注意力的输出。




图 1 高效卷积注意力模块

Fig. 1 Efficient convolutional block attention module

1.1 高效通道注意力子模块

与原始卷积注意力模块中通道注意力子模块相比,高效通道注意力子模块的优势在于能够对通道间的信息进行适当地局部交互^[16]。该子模块根据输入数据的通道数 C ,自动调整通道交互覆盖率 k (即子模块中一维卷积的卷积核尺寸),以保证当前通道的负荷数据信息仅与其相邻的 k 个通道的负荷数据信息进行交互。交互覆盖率 k 的计算式为:

$$k = |t|_{\text{odd}} = \left\lceil \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rceil_{\text{odd}} \quad (1)$$

式中: $|t|_{\text{odd}}$ 表示最靠近 t 的奇数, C 表示输入数据的总通道数, γ 为固定值2, b 为固定值1。利用式(1)确定交互覆盖率 k 后,高效通道注意力子模块将生成的注意力权重在全通道间共享,使模型参数进一步简化,即第 i 个通道 y_i 的权重 w_i 为:

$$w_i = \sigma \left(\sum_{j=1}^k \alpha^j y_i^j \right), \quad y_i^j \in \Omega_i^k \quad (2)$$

式中: σ 为Sigmoid函数, α^j 表示所有通道共享的权重参数, Ω_i^k 代表与 y_i 近邻的 k 个通道的集合。

如图2所示,高效通道注意力子模块通过并行的全局最大池化层和全局平均池化层,顺着空间维度将输入数据进行压缩,聚合特征映射的空间信息。该子模块不再将压缩后的特征送到全连接层中对每个局部信息进行降维和还原操作,而是利用根据通道数自动调整的卷积核大小为 k 的一维卷积,高效地抓取输入数据的跨通道交互信息,并经Sigmoid激活函数输出通道维度上的注意力权重。在高效通道注意力子模块基础上构建的网络,能够更加高效地提取出输入数据在通道维度上的特征,并且在没有增加模型复杂度的同时,显著提升模型性能。




图2 高效通道注意力子模块

Fig. 2 Efficient channel attention submodule

1.2 空间注意力子模块

空间注意力子模块如图3所示。该模块顺着通道维度,首先利用全局最大池化和全局平均池化操作压缩输入的负荷数据,并利用 1×1 卷积替代原始结构中的全连接层,聚合特征映射的通道信息,进而得到两个保留完整空间信息的特征图,然后经Sigmoid函数产生空间注意力权重。

高效卷积注意力模块(ECBAM)中各注意力子模块的全局平均池化能够充分保留输入信息的完整性,而最大值池化操作可以保证网络在反向传播时,只有输入数据中响应最大值部分有梯度的反馈,相较于传统注意力模块可以取得更好的效果。

2 混合膨胀卷积改进的时域卷积网络

时域卷积网络是以CNN为基础,引入擅于抓取长时依赖信息的膨胀因果一维卷积和能够避免梯度消失的残差连接的新网络结构^[17]。




图 3 空间注意力子模块

Fig. 3 Spatial attention submodule

2.1 混合膨胀因果卷积

因果卷积与传统卷积的区别在于,该结构中一层 t 时刻的值只由该时刻之前的值决定,遵守严格的单向约束。受限于卷积核的大小,当对较长的负荷序列建模时,单一的因果卷积可能会面临感受野不足的问题。传统 TCN 将膨胀卷积的膨胀率设置为 $[1, 2, 4, 8]$,使其能够对较长的输入序列有间隔地采样,膨胀卷积感受野如图 4 所示。图 4 中红色圆点为输入数据的中心,白色空心方格为未被采样的输入数据,蓝色实心方格代表经膨胀卷积间隔采样后被扩大的感受野。

从图 4 可以观察到,传统 TCN 的膨胀率 r 设计为 $[1, 2, 4, 8, \dots]$ 的指数增长结构,随着网络层数加深,膨胀卷积结构的感受野大小也会指数倍增加,可以较好地捕获相距较远的负荷数据间的依赖关系,但当网络层数过深时,会导致大量浅层细节负荷数据信息丢失,出现负荷信息不连续的现象,即膨胀卷积的栅格效应问题^[18]。因此,本研究采用混合膨胀卷积(hybrid dilated convolution, HDC)将膨胀率设计为 $[1, 2, 5]$ 的循环结构,其感受野如图 5 所示,其中 S 为膨胀率。混合膨胀卷积的膨胀系数是循环变化的,相当于循环变焦,当膨胀系数增加时,可有效捕获远距离负荷特征;当膨胀系数减小时,可有效捕获大量浅层细节负荷数据信息。经过膨胀卷积操作后最终的感受野可减少遗漏重要负荷信息^[19],尽量避免栅格效应的发生。将混合膨胀卷积结构引入因果卷积构成混合膨胀因果卷积,如图 6 所示。




图 4 膨胀卷积感受野

Fig. 4 Dilated convolutional receptive field




图 5 混合膨胀卷积感受野

Fig. 5 Hybrid dilated convolutional receptive field

2.2 ECBAM-HTCN 短期负荷预测框架

2.2.1 数据集

本研究使用的数据为山东省青岛市电网的历史负荷数据,包含全年记录,并涉及天气状况、日类型等影响因素。其中,负荷单位为兆瓦(MW)。以 15 min 为一个采样间隔,将 24 h 平均分为 96 个点。训练集包含预测日前 15 天的历史负荷数据,测试集为预测日当天负荷数据。输入矩阵(共 29 维)选取与预测日相关性最大的前 3 天的历史负荷数据和当天的影响因素数据,如图 7 所示。

图 7 中, L 为当前时刻负荷数据, T 、 W 、 g 、 d 、 t 分别为温度、天气类型、日类型、日期以及时刻($1 \leq t \leq 96$); L_t^d 为第 d 天 t 时刻的历史负荷值; $T_{\max}^d$ 、 $T_{\min}^d$ 、 T_{ave}^d 为第 d 天的最高、最低和平均气温; W^d 、 g^d 分别为第

d 天的天气和日类型。




图 6 混合膨胀因果卷积

Fig. 6 Hybrid dilation causal convolution




图 7 29 维输入矩阵

Fig. 7 29-dimensional input matrix

2.2.2 ECBAM-HTCN 短期负荷预测模型框架

ECBAM-HTCN 短期负荷预测模型框架如图 8 所示。该框架由基本混合膨胀因果卷积 (HTCN) 残差块嵌套 ECBAM 模块构成的多个 ECBAM-HTCN 模块堆叠而成。首先,通过 HTCN 层对包含历史负荷、温度、日类型等影响因素的输入数据进行学习,将学习到的历史负荷特征输入到高效通道注意力子模块中,通过全局最大和全局平均池化压缩负荷特征空间维度上的依赖信息;然后,根据输入通道数自动调整卷积核尺寸的一维卷积生成通道权重,加权到输入的历史负荷数据上,进而输出带有通道注意力的负荷特征;接着,将提取到的带有通道信息的负荷特征作为空间注意力子模块的输入,同样使用全局平均池化、全局最大池化以及 1×1 卷积进行空间维度下的负荷特征聚合,经 Sigmoid 函数生成的空间注意力加权到输入上,输出兼有通道和空间两个维度注意力的负荷特征;最后,将 ECBAM 模块提取的注意力信息与初始输入的历史负荷数据融合输出,得到预测结果。




图 8 ECBAM-HTCN 短期负荷预测模型框架

Fig. 8 Model framework of ECBAM-HTCN short-term load forecasting

3 算例分析

3.1 模型评估指标及数据预处理

本研究选取负荷预测领域常用的预测精度评估指标,即最大相对误差(maximum relative error, MAX)、均方根误差(root mean square error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE)来评估模型预测效果。

为消除不同数据间量纲差异的影响,对历史负荷数据以及温度等影响因素数据作归一化处理。另外,分别以 0、0.5、1 表示日类型影响因素中的节假日、休息日和工作日,天气影响因素包含雨雪、晴天和多云。

3.2 实验设置

本研究实验硬件配置为 Intel © Core™ i5-5200U CPU, 8 GB RAM, 编程语言为 Python, 模型搭建框架为 Pytorch 1.8.0; ECBAM-HTCN 短期负荷预测模型由 4 个 ECBAM-HTCN 残差块堆叠而成, 各层卷积核大小均为 2; 使用 Adam 优化算法、均方差函数作为模型优化器和损失函数; 设置残差块膨胀系数为 [1, 2, 5] 的循环结构, 滤波器数量为 [16, 8, 4, 1]; 训练轮次为 100, 初始学习率等于 0.01。

3.3 仿真结果分析

为验证 ECBAM-HTCN 模型(模型 1)预测结果的有效性, 将未经 ECBAM 模块优化的 HTCN 模型记为模型 2, 传统 TCN 模型记为模型 3, 一维 CNN 记为模型 4, GRU 模型记为模型 5, 利用上述 5 个模型对某春季工作日的电力负荷进行预测。5 种模型预测曲线及误差对比见图 9 和表 1。从图 9 可以看出, 模型 1 的预测曲线与真实的历史负荷曲线拟合程度优于其他 4 个模型。

结合图 9 和表 1 可知, 模型 1 具有更高的预测精度。相较于模型 2、模型 3、模型 4 和模型 5, 模型 1 的 MAPE 分别降低了 0.21%、0.56%、0.97% 和 1.11%; RMSE 分别降低了 6.68、19.05、32.11 和 29.03 MW; MAX 分别降低了 0.40%、2.34%、1.93% 和 1.38%。实验结果表明 ECBAM-HTCN 模型具有更好的负荷预测效果。

为验证模型 1 的稳定性, 在春季(4 月 19—25 日)进行连续一周的负荷预测, 结果见表 2。从表 2 可知, 模型 1 连续 7 天的平均预测精度达 98.85%, 充分表明 ECBAM-HTCN 模型具有较好的预测稳定性。

为验证模型 1 在夏季(7 月 7—13 日)高温期的预测效果, 选取夏季连续一周的电力负荷数据进行预测, 结果如表 3 所示。综合分析表 2 和表 3 可知, 模型 1 能够适应不同季节下的负荷变化情况, 并保持良好的预测精度。

为评估 ECBAM 模块和混合膨胀卷积结构对模型性能的影响, 对上述春季连续一周的历史负荷数据进行预测, 从参数量和预测精度两方面对模型进行了消融实验。同时, 增加了未改进的融合传统卷积注意力模块 HTCN 模型(HTCN with convolutional block attention module, CBAM-HTCN), 即模型 6, 和多尺度特征增强的 DHTCN 模型^[19](模型 7)进行对比试验。评估结果如图 10 所示。




图 9 5 种模型负荷预测曲线对比图

Fig. 9 Comparison of load forecasting curves for five models

表 1 5 种模型误差对比

Table 1 Comparison of errors for five models

模型	MAPE/%	RMSE/MW	MAX/%
模型 1	1.01	31.12	3.08
模型 2	1.22	37.80	3.48
模型 3	1.57	50.17	5.42
模型 4	1.98	63.23	5.01
模型 5	2.12	60.15	4.46

表 2 模型 1 在春季连续一周预测结果

Table 2 Forecast results for a consecutive week in spring

日期	MAPE/%	RMSE/MW	MAX/%
4 月 19 日	1.39	45.52	4.17
4 月 20 日	1.14	33.92	3.17
4 月 21 日	1.01	31.12	3.08
4 月 22 日	1.03	32.03	3.78
4 月 23 日	1.08	31.57	3.25
4 月 24 日	1.33	37.93	5.88
4 月 25 日	1.07	29.86	2.62
平均值	1.15	34.56	3.71

表 3 模型 1 在夏季连续一周预测结果

Table 3 Forecast results for a consecutive week in summer

日期	MAPE/%	RMSE/MW	MAX/%
7 月 7 日	1.26	39.52	3.56
7 月 8 日	1.30	44.63	3.67
7 月 9 日	1.39	42.38	4.63
7 月 10 日	1.57	44.78	4.03
7 月 11 日	1.50	44.87	3.87
7 月 12 日	1.63	55.16	4.65
7 月 13 日	1.38	47.83	5.87
平均值	1.43	45.60	4.33

对比模型 1 和模型 6 可以看出,ECBAM 模块大幅度减少了模型参数量;相较于模型 7,模型 1 能够有效减轻模型负担,并保持较高的预测精度。综合对比几个模型可知,本研究提出的预测模型能够有效减少模型参数量,并保持较高的预测精度。

4 结论

本研究提出 ECBAM 模块并引入混合膨胀卷积结构改进时域卷积网络,针对短期电力负荷预测提出 ECBAM-HTCN 短期负荷预测模型。该模型有以下优点:

- 1) 引入混合膨胀卷积结构,在膨胀卷积不增加参数和计算量的情况下增加感受野,能克服传统时域卷积网络中膨胀卷积结构导致的信息不连续问题,有效地捕捉负荷数据更大范围的全局依赖关系;同时,充分利用时域卷积网络对时间序列的强大挖掘能力以及可并行运算的高效数据处理能力,完成高精度的负荷预测。
- 2) 提出 ECBAM 模块,兼顾空间和通道两个维度的重要负荷信息表达,利用两种一维卷积改进 CBAM 子模块中的全连接层,能高效地捕获负荷数据通道间的交互信息、减少网络参数,有效协调模型预测准确性与复杂度之间的关系。

参考文献:

[1] PARIZY E S,CHOI S,BAHRAMI H R. Grid-specific co-optimization of incentive for generation planning in power systems with renewable energy sources[J]. IEEE Transactions on Sustainable Energy,2020,11(2):947-957.

[2] VISSER L R,KOOTE M E,FERREIRA A C,et al. An operational bidding framework for aggregated electric vehicles on the electricity spot market[J/OL]. Applied Energy,2022,308. DOI:10.1016/j.apenergy. 2021.118280.

[3] 白星振,赵康,葛磊蛟,等. 基于 EWT-GRU-RR 的配电网短期电力负荷预测模型[J]. 山东科技大学学报(自然科学版), 2023,42(5):77-87.

BAI Xingzhen,ZHAO Kang,GE Leijiao,et al. Short-term power load forecasting model based on EWT-GRU-RR[J]. Journal of Shandong University of Science and Technology(Natural Science),2023,42(5):77-87.

[4] 王继东,杜冲. 基于 Attention-BiLSTM 神经网络和气象数据修正的短期负荷预测模型[J]. 电力自动化设备,2022,42(4):172-177.

WANG Jidong,DU Chong. Short-term load prediction model based on Attention-BiLSTM neural network and meteorological data correction[J]. Electric Power Automation Equipment,2022,42(4):172-177.




图 10 5 种模型对比结果

Fig. 10 Comparison results of five models

- [5] BENTO P M R, POMBO J A N, CALADO M R A, et al. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting[J]. Neurocomputing, 2019(358): 53-71.
- [6] DONG X S, QIAN L J, HUANG L. A CNN based bagging learning approach to short-term load forecasting in smart grid [C]//2017 IEEE SmartWorld, Ubiquitous Intelligence Computing, Advanced Trusted Computed, Scalable Computing Communications, Cloud Big Data Computing, Internet of People and Smart City Innovation. IEEE, 2017: 1-6.
- [7] 王文卿, 搬奥洋, 于立涛, 等. 自编码器与 PSOA-CNN 结合的短期负荷预测模型[J]. 山东大学学报(理学版), 2019, 54(7): 50-56.
WANG Wenqing, HAN Aoyang, YU Litao, et al. Short-term load forecasting model based on autoencoder and PSOA-CNN [J]. Journal of Shandong University(Natural Science), 2019, 54(7): 50-56.
- [8] 许言路, 武志锴, 朱赫炎, 等. 基于多尺度卷积神经网络的短期电力负荷预测[J]. 沈阳工业大学学报, 2020, 42(6): 618-623.
XU Yanlu, WU Zhikai, ZHU Heyan, et al. Short-term power load forecasting based on multi-scale convolutional neural network[J]. Journal of Shenyang University of Technology, 2020, 42(6): 618-623.
- [9] 王淞瑶, 张智晟. 基于量子加权多层级 GRU 神经网络的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2022, 50(23): 85-93.
WANG Songyao, ZHANG Zhisheng. Short-term multivariate load forecasting of an integrated energy system based on a quantum weighted multi-hierarchy gated recurrent unit neural network[J]. Power System Protection and Control, 2022, 50(23): 85-93.
- [10] LEA C, FLYNN M D, VIDAL R, et al. Temporal convolutional networks for action segmentation and detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 1003-1012.
- [11] 赵洋, 王瀚墨, 康丽, 等. 基于时间卷积网络的短期电力负荷预测[J]. 电工技术学报, 2022, 37(5): 1242-1251.
ZHAO Yang, WANG Hanmo, KANG Li, et al. Temporal convolutional network-based short-term electrical load forecasting[J]. Transactions of China Electrotechnical Society, 2022, 37(5): 1242-1251.
- [12] 杨国华, 郑豪丰, 张鸿皓, 等. 基于 Holt-Winters 指数平滑和时间卷积网络的短期负荷预测[J]. 电力系统自动化, 2022, 46(6): 73-82.
YANG Guohua, ZHENG Haofeng, ZHANG Honghao, et al. Short-term load forecasting based on Holt Winters exponential smoothing and temporal convolutional network[J]. Automation of Electric Power Systems, 2022, 46(6): 73-82.
- [13] 毛力, 张艺楠, 孙俊. 融合注意力与时域多尺度卷积的手势识别算法[J]. 计算机应用研究, 2022, 39(7): 2196-2202.
MAO Li, ZHANG Yinan, SUN Jun. Gesture recognition algorithm combining attention and time-domain multiscale convolution[J]. Application Research of Computers, 2022, 39(7): 2196-2202.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of Computer Vision-ECV 2018, 15th European Conference, Part VII. Cham: Springer International Publishing, 2018: 3-19.
- [15] 毛志荣, 都云程, 肖诗斌, 等. 基于 ECA-Net 与多尺度结合的细粒度图像分类方法[J]. 计算机应用研究, 2021, 38(11): 3484-3488.
MAO Zhirong, DU Yuncheng, XIAO Shibin, et al. Fine-grained image classification method based on ECA-Net and multi-scale[J]. Application Research of Computers, 2021, 38(11): 3484-3488.
- [16] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient Channel Attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 11531-11539.
- [17] 徐先峰, 赵依, 刘状壮, 等. 用于短期电力负荷预测的日负荷特性分类及特征集重构策略. 电网技术, 2022, 46(4): 1548-1556.
XU Xianfeng, ZHAO Yi, LIU Zhuangzhaung, et al. Daily load characteristic classification and feature set reconstruction strategy for short-term power load forecasting[J]. Power System Technology, 2022, 46(4): 1548-1556.
- [18] XUE Z H, ZHANG M X. Multiview low-rank hybrid dilated network for SAR target recognition using limited training samples[J]. IEEE Access, 2020, 8: 227847-227856.
- [19] 梁露, 张智晟. 基于多尺度特征增强 DHTCN 的电力系统短期负荷预测研究[J]. 电力系统保护与控制, 2023, 51(10): 172-179.
LIANG Lu, ZHANG Zhisheng. Short-term load forecasting of power system based on multi-scale feature enhanced DHTCN[J]. Power System Protection and Control, 2023, 51(10): 172-179.

(责任编辑: 齐敏华)